

基于卷积神经网络和迁移学习的奶牛个体识别

邢永鑫, 吴碧巧, 吴松平, 王天一*

贵州大学大数据与信息工程学院, 贵州 贵阳 550025

摘要 为了实现对复杂养殖场环境下奶牛个体的精准识别, 针对 SSD (single shot multibox detector) 算法对重叠对象检测效果不好的问题, 对 SSD 算法进行改进。通过将不同特征图的特征进行融合, 使得不同特征图的信息可以互补, 从而改善算法对重叠对象的检测效果; 去掉网络中的 Conv4_3 层特征图, 同时增加其他特征图候选框的数量, 这样不仅可以保证算法的实时性, 而且提高了检测精度; 引入迁移学习方法, 以提高算法的平均准确率。实验结果表明: 改进的 SSD 算法与传统 SSD 算法相比, 在满足实时检测的情况下, 平均准确率 (AP) 提高 4.32%; 经过迁移后, 改进 SSD 算法的 AP 提高 3.85%。

关键词 图像处理; 人工智能; 目标识别; 卷积神经网络; 特征融合; 迁移学习

中图分类号 TP389

文献标志码 A

doi: 10.3788/LOP202158.1628002

Individual Cow Recognition Based on Convolution Neural Network and Transfer Learning

Xing Yongxin, Wu Biqiao, Wu Songping, Wang Tianyi*

College of Big Data and Information Engineering, Guizhou University, Guiyang 550025, Guizhou, China

Abstract To realize accurate identification of individual cows in a complex farm environment, the SSD (single shot multibox detector) algorithm was improved to solve the problem of poor detection effect for overlapping objects. First, different feature maps were fused to ensure that different feature maps complemented each other and improved the detection effect of overlapping objects. Then, Conv4_3 was removed from the network. The number of candidate frames in other feature maps increased, ensuring the real-time performance of the algorithm and also improving the detection accuracy. Finally, the transfer learning method was used to improve the average accuracy of the algorithm. The experimental results show that compared with the traditional SSD algorithm, the average accuracy (AP) of the improved SSD algorithm is improved by 4.32% in real-time detection, and the AP of the improved SSD algorithm is increased by 3.85% after migration.

Key words image processing; artificial intelligence; target recognition; convolutional neural network; feature fusion; transfer learning

OCIS codes 100.3008; 100.2000; 100.2970

1 引言

随着国内奶牛养殖业的快速发展, 企业化、大规模养殖成为主流方向。奶牛个体识别对牧场奶牛的管理至关重要^[1-2]。针对奶牛的识别方法主要有人工观测法^[3]、刻耳法^[4]、电子识别方法^[5-6]等。这些

方法不仅会对奶牛造成损害, 而且工作繁琐, 劳动强度大。

随着深度学习的出现, 深度学习算法得到广泛的关注和应用。深度学习算法具有极强的特征学习和表达能力, 在图像识别和特征提取方面优势突出, 大大促进了目标识别领域的发展。卷积神经网络

收稿日期: 2020-09-30; 修回日期: 2020-10-30; 录用日期: 2020-12-08

基金项目: 贵州省科技支撑计划(SY[2017]2881)

通信作者: *tywang@gzu.edu.cn

(CNN)是基于深度学习的一种学习算法,CNN 利用逐层深入的空间关系来减少需要学习的参数量,以提高一般神经网络算法的训练性能,在 CNN 中,最底层的输入为图像的局部感受区域,将图片输入到一个卷积层后,图片特征经过不同的权值矩阵,将权值与输入特征进行卷积运算,以滑动窗口的形式进行运算,滑动方向为从左到右、从上到下,运算方式为通道与前一卷积层对应位置的数字相乘然后求和。以滑动窗口的形式进行运算,滑动方向为从左到右、从上到下,运算方式为通道与前一卷积层对应位置的数字相乘然后求和。然后加上偏置,基于非线性激活函数,得到下层卷积层输入数据特征,特征信息在不同的层中依次传递。拥有深度架构的 CNN 往往有更好的预测效果,但是深度 CNN 一直以来存在一种缺陷,即它是一种由数据驱动的算法,通常需要大量的数据来训练网络,因此获得大量训练数据成为急需解决的问题。迁移学习的出现很好地解决了这个问题。迁移学习^[7]不同于传统的深度学习,其本质是将某个领域学习到的知识或模式应用到不同但相关的领域中,将大数据迁移到小数据领域,以解决小数据领域中数据稀缺、知识稀缺的问

题,从而有效地解决训练数据不足导致模型不收敛或者过拟合的问题^[8]。

为了实现对奶牛的精确识别,本文对 SSD 算法^[9]进行改进。首先,为了充分利用每个特征层的特征信息,对 SSD 算法的特征图进行特征融合,将包含细节信息的浅层特征图与包含语义信息的深层特征图融合,这样不但有利于目标分类,而且预测物体的位置也更加准确。然后,结合 FriesianCattle2017 数据集中基本没有小目标物体的特点,去掉网络中的 Conv4_3 层,同时增加其他特征图候选框的数量,以提高算法的检测精度,最后引入迁移学习。

2 卷积神经网络

2.1 SSD 卷积神经网络

SSD 目标检测算法是由 Liu 在 ECCV (European conference on computer vision)会议上提出的。相比于 Faster R-CNN 等双阶段检测算法,SSD 算法属于单阶段目标检测算法,通过在不同尺度感受野的特征图上提取特征,利用回归得到目标物体的位置和分类结果。

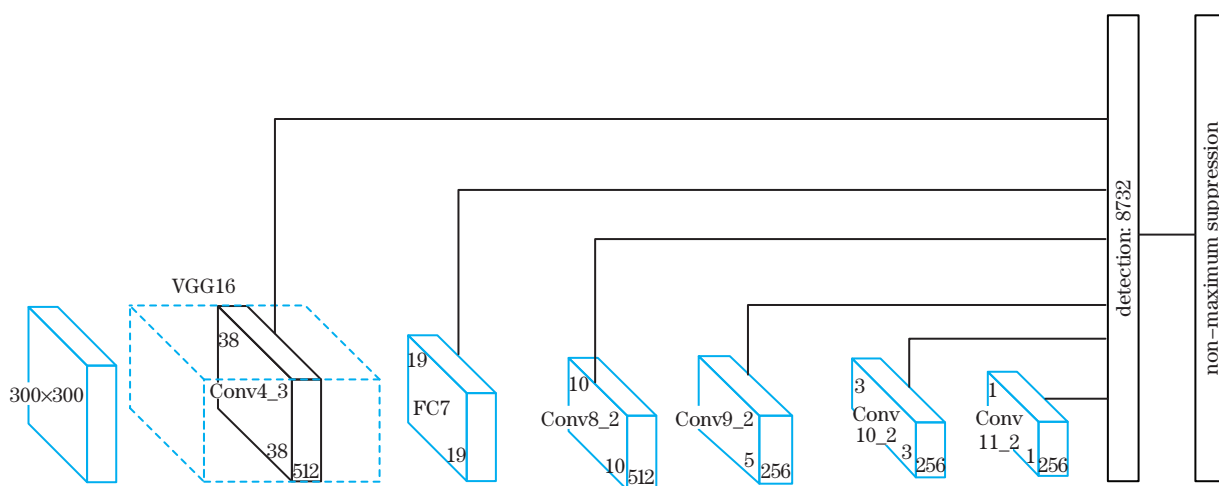


图 1 SSD 网络结构

Fig. 1 SSD network structure

如图 1 所示,SSD 算法的主干网络为 VGG16,将 VGG16 网络的 FC6、FC7 层改为 Conv6、Conv7 层,然后在后面加了 4 个卷积层,构成 SSD 算法框架。整个网络结构有 6 个特征图,分别用于预测不同尺寸的物体,浅层特征图的分辨率高、感受野小,用来预测小物体目标,深层特征图则用来预测较大的物体目标。表 1 列出了每个特征图的参数,最后经过非极大值抑制预测目标物体。

表 1 SSD 算法候选框参数设置

Feature map	$M \times N$	K	Aspect ratio	Number of candidate frames
Conv4_3	38×38	4	1, 2	5776
FC7	19×19	6	1, 2, 3	2166
Conv8_2	10×10	6	1, 2, 3	600
Conv9_2	5×5	6	1, 2, 3	150
Conv10_2	3×3	4	1, 2	36
Conv11_2	1×1	4	1, 2	4

SSD 算法采用 6 个特征图生成不同尺寸的候选框,每个特征图的大小为 $M \times N$,就是将对应的特征图划分成 $M \times N$ 个网格,然后以每个网格的中心点为中心,产生 K 个候选框,则每个特征图产生候选框的数量为 $M \times N \times K$,总共产生 8732 个候选框。在 Conv4_3,Conv10_2,Conv11_2 层,每个网格产生 4 个候选框;FC7,Conv8_2,Conv9_2 层中每个网格产生 6 个候选框。

候选框参数可表示为

$$S_K = S_{\min} + \frac{S_{\max} - S_{\min}}{m - 1}(K - 1), K \in [1, m), \quad (1)$$

式中: S_K 为第 K 个特征图的 min_size 参数,max_size 的值为 S_{K+1} ; S_{\min} 为设置好的最小归一化尺寸,取值为 0.2; S_{\max} 为设置好的最大归一化尺寸,取值为 0.9; m 为特征图的数量(SSD 算法中 $m=6$)。

当每个网格产生 4 个候选框时,以网格的中心点为中心会产生 2 个正方形和 2 个长方形。2 个正方形对应的边长分别为 $300S_K$ 和 $300\sqrt{S_K S_{K+1}}$ 。

2 个长方形对应的边长分别为 $300RS_K, 300S_K/\sqrt{R}$ 和 $300S_K\sqrt{1/R}, 300S_K/\sqrt{1/R}$,其中 R 为纵横比。当产生 4 个候选框时, $R = \{1, 2\}$,当产生 6 个候选框时, $R = \{1, 2, 3\}$,300 为 SSD 算法输入图片的尺寸。

2.2 改进 SSD 卷积神经网络

在 SSD 网络结构中,浅层特征图的分辨率更高,包含更多细节信息,但是由于经过的卷积更少,其语义性更低,噪声更多。深层特征图具有更强的语义信息,但是分辨率很低,对细节的感知能力较差。为了充分利用浅层细节信息与深层语义信息,本文将深层特征图与浅层特征图进行融合,以改善对重叠对象的检测效果。

图 2 为改进 SSD 算法的网络结构。改进 SSD 算法的主干网络是 VGG16,相比于 SSD 算法,该算法有 5 个输出特征图,并且用通道合并的方法将 5 个特征图进行融合,增强了对重叠对象的检测效果。同时通过重构候选框,使得改进 SSD 算法有 3948 个候选框。

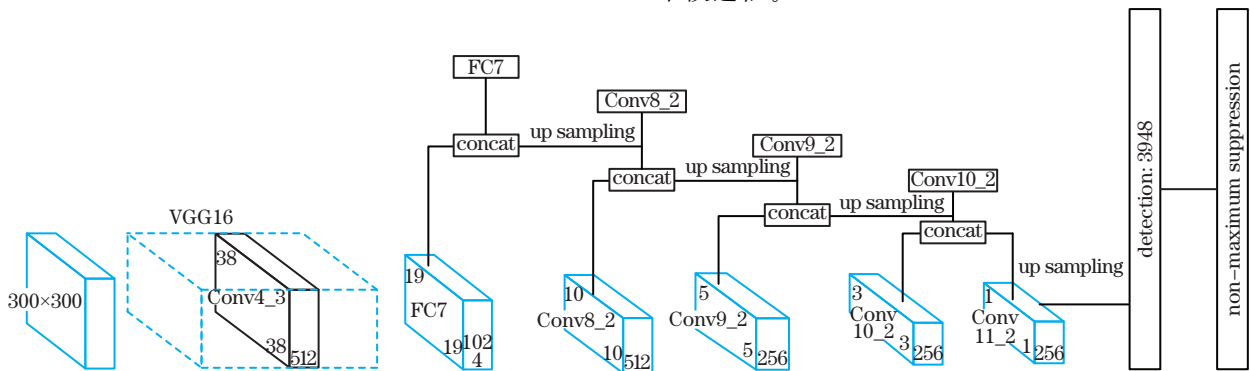


图 2 改进 SSD 网络结构

Fig. 2 Improvement of SSD network structure

2.3 特征融合方式

网络模型中有两种特征融合方式,ResNet、FPN 等网络结构采用 element-wise add 来进行特征融合,而 DenseNet、Inception 等采用 concat 来进行特征融合。由图 3 可知,concat 代表通道数的拼接,而 add 代表特征图相加。add 和 concat 相比,add 共用一个通道,因此在进行融合时,两个特征图的通道数必须相同。这样导致数据维度较少,信息有所损失;特征融合中,相加部分的权重始终相同。而 concat 允许融合信息有不同的参数。concat 融合使得通道数增加,网络会提取到物体更多的整体信息,但是计算量也会较大。为了确定使用哪种融合方式,本文在两种不同的融合方式下进行实验。表 2 为不同融合方式下上采

样层参数的设置。由实验结果可知,在检测时间基本相等的情况下,通道拼接融合方式的平均准确率更高,因此本文选择通道拼接融合方式。




图 3 不同融合方式

Fig. 3 Different fusion methods

表 2 不同融合方式下上采样层参数设置

Table 2 Parameter setting of upper sampling layer under different fusion modes

Upper sampling layer	Number of output channels		Kernel_size	Stride	Padding
	concat	add			
Conv11_2	256	256	3	3	Same
Conv10_2	256	256	3	1	Valid
Conv9_2	512	512	3	2	Same
Conv8_2	512	1024	10	1	Valid

2.4 候选框重构

为了增加候选框的数量,使得网络可以学习到更加准确的回归关系,减小候选框数量过少带来的影响并提高算法精度,对候选框进行重构。表 3 为改进 SSD 算法中候选框参数的设置。

表 3 改进 SSD 算法中候选框参数设置

Table 3 Parameter setting of candidate frame of improved SSD algorithm

Feature map	$M \times N$	K	Aspect_ratio	Number of candidate frames	Total number of candidate frames
FC7	19×19	8	1,2,3,4	2888	3948
Conv8_2	10×10	8	1,2,3,4	800	
Conv9_2	5×5	8	1,2,3,4	200	
Conv10_2	3×3	6	1,2,3	54	
Conv11_2	1×1	6	1,2,3	6	

在 SSD 算法中,6 个特征图生成不同尺寸的候选框。如果特征图的大小为 $M \times N$,在每个单元点设置 K 个候选框,则一个特征图生成候选框的个数为 $M \times N \times K$,本文将 SSD 算法中的 6 个特征图改为 5 个特征图。 K 的取值由 $\{6,6,6,4,4\}$ 改为 $\{8,8,8,6,6\}$,然后将 FC7,Conv8_2,Conv9_2 层候选框的纵横比设置为 $\{1,2,3,4\}$,Conv10_2,Conv11_2 层候选框的纵横比设置为 $\{1,2,3\}$ 。

3 迁移学习

迁移学习^[10-11]是对小样本进行监督学习的一种崭新策略。通过模型参数共享,将在大规模数据集中预训练好的网络模型嵌入到其他任务模型中,作为其他任务的特征提取器。如图 4 所示,从源域中训练

模型,将从源域中训练学到的知识和卷积神经网络迁移到目标域,然后在目标域上重新设计一个分类层,将其迁移过来的网络模型重新组建为一个新的卷积神经网络,用来训练目标域图像数据。迁移学习的关键是源任务领域和目标任务领域要有相关性,如图 4 所示,本文的目标任务是对奶牛进行识别,那么可以选择其他相关性的哺乳动物作为原数据域对模型进行预训练,最后对模型进行微调,从而达到比较好的识别效果。实验中采用两种方法^[12]进行训练:1)冻结特征提取层,只训练分类层;2)所有层都训练。

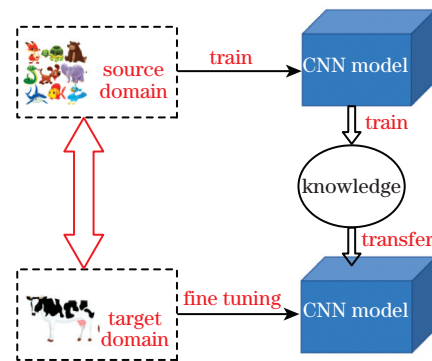


图 4 迁移学习过程

Fig. 4 Transfer learning process

4 实验结果与分析

4.1 实验环境

本次实验在 python3.7, tensorflow2.0 环境下进行,用 labelimg 标注数据集,用 keras 构建网络结构,用 RTX 2080Ti 加速训练,CPU:i7-9700 3.6k@3.60 GHz×8。

4.2 数据集

由于本文用于训练的数据较少,且迁移学习方法的场景针对性强,能很好地解决训练数据不足引起的过拟合问题,所以本文使用迁移学习方法训练模型。实验用 VOC2012 数据集进行预训练,得到预训练模型。奶牛数据为 FriesianCattle2017 数据集,总共 940 张图片,按照 6:2:2 的比例分为训练集、验证集、测试集。图 5 为奶牛标注图片。

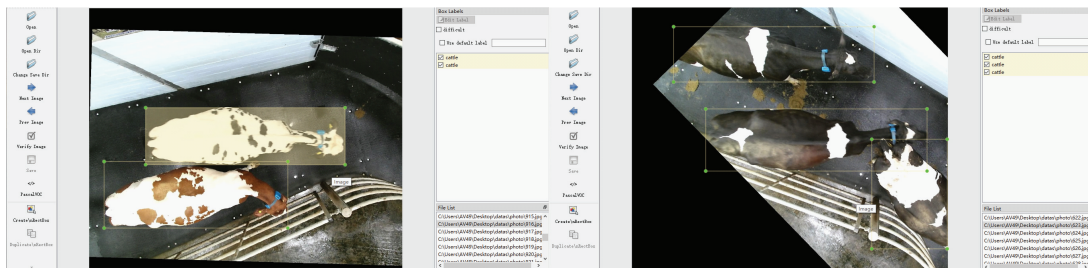


图 5 奶牛标注图片

Fig. 5 Cow labeling pictures

4.3 评价指标

实验通过在测试集中分析模型改进前后的精确率、召回率、平均准确率和平均检测时间,对比模型的性能。其中,精确率是精确性的度量,表示被分为正例的示例中实际为正例的比例;召回率是覆盖面的度量,表示所有正例中被分对的比例。平均准确率(AP,可用 P_{AP} 表示)为精确率关于召回率的函数曲线与坐标轴 0 到 1 范围围成的面积,AP 值越高,代表检测性能越好。精确率(P)和召回率(R)的指标定义为

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (2)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (3)$$

式中: N_{TP} 为检测模型将奶牛目标检测对的数量; N_{FP} 为检测模型将非奶牛目标检测为奶牛目标的数量; N_{FN} 为检测模型将非奶牛目标检测对的数量。

AP 的积分公式为

$$P_{AP} = \int_0^1 P(r) dr, \quad (4)$$

式中: $P(r)$ 为精确率关于召回率的函数; r 为召回率。

4.4 实验结果

4.4.1 不同融合方式的实验结果

由表 4 可知,特征增加融合方式的平均准确率最低,虽然通道拼接融合方式的平均检测时间长,但基本满足实时检测的要求,且其平均准确率比传统方法高 2.35%,比特征增加融合的方式高 2.47%。因此本文选择通道拼接融合方式。

表 4 不同融合方式在测试集上的实验结果

Table 4 Experimental results on test sets of different fusion methods

Experimental algorithm	Feature fusion	Fusion method	$P_{AP}/\%$	Average detection time /ms
SSD			88.23	46.23
SSD	✓	Add	88.11	51.52
SSD	✓	Concat	90.58	54.04

4.4.2 SSD 算法与改进 SSD 算法在测试集上的实验结果

由表 5 可知,改进 SSD 算法和传统 SSD 算法相比,虽然平均检测时间增加 7.93 ms,但是精确率提高了 1.13%,召回率提高 4.28%,平均准确率提高了 4.32%,算法性能得到明显改善。

图 6 中以垂直直线进行区分,最左边为 SSD 算法的 P - R 曲线,最右边为改进 SSD 算法的 P - R 曲

线。其中垂直直线部分不在 P - R 曲线内,使用垂直直线只是为了区分不同的 P - R 曲线、体现不同算法之间的差异。

表 5 SSD 算法与改进 SSD 算法在测试集上的实验结果

Table 5 Experimental results of SSD algorithm and improved SSD algorithm on test set

Experimental algorithm	$N_{TP}/N_{FP}/N_{FN}$	$P/\%$	$R/\%$	$P_{AP}/\%$	Average detection time /ms
SSD	454/12/60	97.42	88.32	88.23	46.23
Improved SSD	476/7/38	98.55	92.60	92.55	54.16

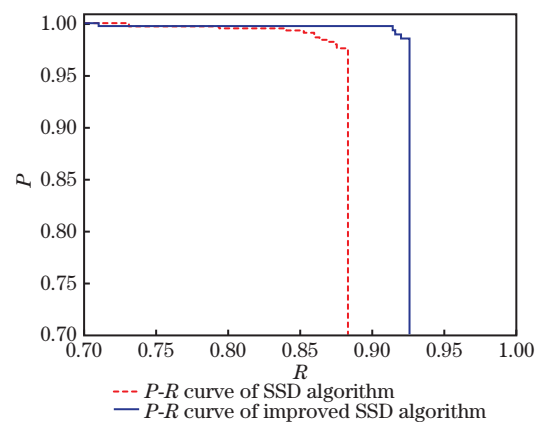


图 6 不同算法的 P - R 曲线

Fig. 6 P - R curves of different algorithms

图 7 为改进 SSD 算法与 SSD 算法的检测结果,图 7(a)为改进 SSD 算法的检测结果,图 7(b)为 SSD 算法的检测结果。图 7 左边两幅图中两个物体的重合度较高且有遮挡,SSD 算法只检测到 3 个目标,而改进 SSD 算法检测到 4 个目标;在右边两幅图中,两个物体有重叠,SSD 算法只检测到 3 个目标,而改进 SSD 算法检测到 4 个目标。由检测结果对比可知,改进 SSD 算法改善了 SSD 算法对于重叠对象检测不佳的问题。

4.4.3 基于迁移学习在不同算法中的实验结果

由表 6 可知,迁移学习只训练分类层的训练方式在测试集上的平均准确率最低。迁移学习只训练分类层的训练方式在测试集上的平均准确率最低。改进 SSD 算法的平均准确率为 75.24%。其原因是迁移参数权重的特征提取层虽然可以提取图像的特征,但 FriesianCattle2017 数据集与 VOC2012 数据集存在较大差异,仅训练分类层不能达到理想的效果。而训练全部层可以明显提高测试的平均准确率,平均准确率达到 96.40%,和全新训练方式相比,其平均准确率提高 3.85%。

实验用 Adam 优化器,初始学习率为 0.0001,

batch_size 设置为 16, 为了防止过拟合, 实验中使用了早停, 当有 10 个 epoch 的验证集损失值不下降时, 自动停止训练。由图 8 可以看出全新学习训练方式的收敛速度最慢。迁移学习只训练分类层的收敛速

度较全新学习快一些, 最后趋于平稳。因为只训练分类层, 前面特征提取层参数得不到更新, 所以 loss 值稳定在 1 附近。迁移学习训练全部层的收敛速度最快, 表明迁移学习缩短了模型收敛所需的时间。




图 7 改进 SSD 算法与 SSD 算法的检测效果。(a)改进 SSD 算法;(b) SSD 算法

Fig. 7 Detection effect of improved SSD algorithm and SSD algorithm. (a) Improved SSD algorithm; (b) SSD algorithm

表 6 不同训练方式在测试集上的实验结果

Table 6 Experimental results of different training methods on test set

Experimental algorithm	Training method	$N_{TP}/N_{FP}/N_{FN}$	$P / \%$	$R / \%$	$P_{AP} / \%$
SSD	New training	454/12/60	97.42	88.32	88.23
SSD	Transfer learning only trains classification layer	368/3/146	99.19	71.59	71.56
SSD	Transfer all levels of learning and training	477/8/37	98.35	92.80	92.69
Improved SSD	New training	476/7/38	98.55	92.60	92.55
Improved SSD	Transfer learning only trains classification layer	388/11/126	97.24	75.48	75.24
Improved SSD	Transfer all levels of learning and training	496/7/18	98.60	96.49	96.40

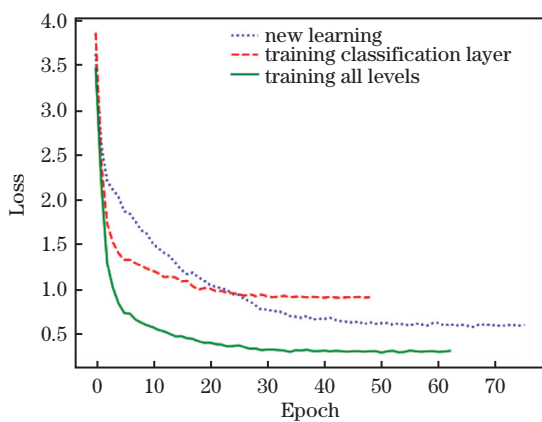


图 8 改进 SSD 算法在不同训练方式下在训练集上的损失曲线

Fig. 8 Loss curves of improved SSD algorithms under different training methods on training set

图 9 中以垂直直线进行区分, 最左边为迁移学习只训练分类层的 $P-R$ 曲线, 中间为全新学习的

$P-R$ 曲线, 最右边为迁移学习训练全部层的 $P-R$ 曲线。

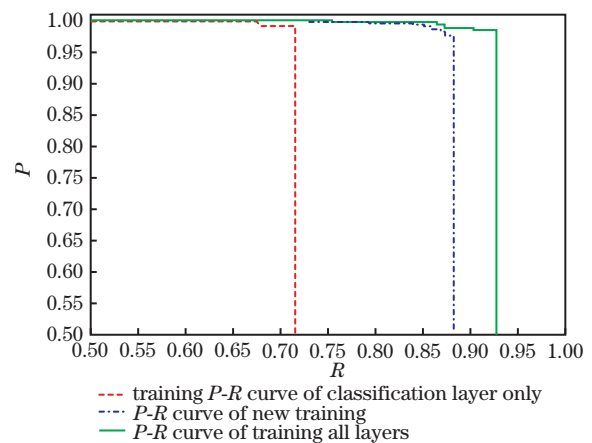


图 9 SSD 算法在不同训练方式下的 $P-R$ 曲线

Fig. 9 $P-R$ curves of SSD algorithm with different training methods

图 10 中以垂直直线进行区分,三条曲线分别为迁移学习只训练分类层、全新学习、迁移学习训练全部层的 $P-R$ 曲线。

图 11(a)为迁移学习只训练分类层的检测结果,图 11(b)为全新学习的检测结果,图 11(c)为迁移学习训练全部层的检测结果。

图 12(a)为迁移学习训练全部层的检测结果,图 12(b)为全新学习的检测结果,图 12(c)为迁移学习只训练分类层的检测结果。

4.4.4 迁移学习后目标域训练集的大小对识别精度的影响

表 7 为迁移学习后训练集的大小对识别精度的影响。由实验结果可知,在 FriesianCattle2017 数据集中,用 20% 的训练集与 50% 的训练集训练得到的实验结果相差较大,用 50% 的训练集训练得到的实验结果与用 80% 的训练集和全部训练集得到的实

验结果相差不大,因此训练集的大小对识别精度有影响。且当用 50% 的训练集进行训练时,可得到比较好的实验结果。




图 10 改进 SSD 算法在不同训练方式下的 $P-R$ 曲线
Fig. 10 $P-R$ curves of improved SSD algorithm with different training methods




图 11 SSD 算法在不同训练方式下的检测效果。(a)迁移学习只训练分类层;(b)全新学习;(c)迁移学习训练全部层
Fig. 11 Detection effect of SSD algorithm with different training methods. (a) Transfer learning trains only the classification layer; (b) new study; (c) transfer learning trains all layers

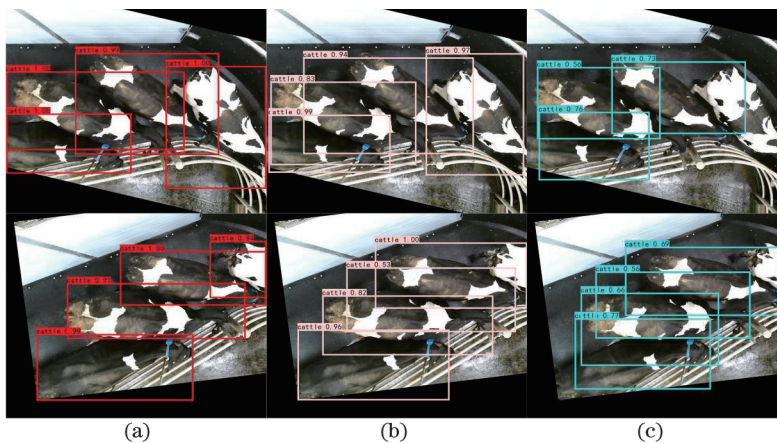


图 12 改进 SSD 算法在不同训练方式下的检测效果。(a)迁移学习训练全部层;(b)全新学习;(c)迁移学习只训练分类层
Fig. 12 Detection effect of improved SSD algorithm under different training methods. (a) Transfer learning trains all layers; (b) new study; (c) transfer learning trains only classification layer

表 7 迁移学习后目标域训练集的大小对识别精度的影响

Table 7 Influence of training set size of target domain on recognition accuracy after transfer learning

Algorithm	20% of the training set	50% of the training set	80% of the training set	All training set
SSD	87.24	92.94	93.13	92.69
Improved SSD	91.73	95.10	95.66	96.40

4.4.5 不同算法在测试集上的平均准确率

表 8 为不同算法的检测结果。文献[13]中将主干网络由 VGG16 换为 MobileNet 网络,这样可以降低网络运算量,提高检测速度;文献[14]将主干网络由 VGG16 换为 DesNet121 网络,同时为了防止过拟合,使用数据增强以提高算法的精确度。由实验结果可知,虽然 YOLOV2 算法和文献 13 中方法的检测时间少,但是检测精度较低。本文方法与 YOLOV3 算法和文献[14]中方法相比,可在保证检测时间的同时提高检测精度。

表 8 不同算法的平均准确率

Table 8 Average accuracy of different algorithms

Algorithm	$P_{AP}/\%$	Average detection time /ms
SSD	88.23	46.23
YOLOV2	85.26	20.49
YOLOV3	90.80	53.24
Method in Ref. [13]	85.46	19.64
Method in Ref. [14]	93.21	55.01
Method in this paper	96.40	54.16

5 结 论

针对 SSD 算法对 FriesianCattle2017 数据集中奶牛重叠对象检测效果不好的问题,提出了改进 SSD 算法。对不同特征图进行特征融合,并引入迁移学习训练网络,以提高算法的检测精度。实验结果表明,改进后的 SSD 算法可明显提升对奶牛的检测效果,解决了 SSD 算法对重叠对象检测效果不佳的问题。相比于其他主流算法,本文算法有很高的准确率,在智能化养殖方面有很好的应用前景。

参 考 文 献

[1] Ball J E, Anderson D T, Chan C S, Sr. Comprehensive survey of deep learning in remote sensing: theories, tools, and challenges for the community[J]. Journal of Applied Remote Sensing, 2017, 11(4): 042609.

[2] Santoni M M, Sensuse D I, Arymurthy A M, et al. Cattle race classification using gray level co-

occurrence matrix convolutional neural networks[J]. Procedia Computer Science, 2015, 59: 493-502.

- [3] Neethirajan S, Tuteja S K, Huang S T, et al. Recent advancement in biosensors technology for animal and livestock health management [J]. Biosensors and Bioelectronics, 2017, 98: 398-407.
- [4] Awad A I. From classical methods to animal biometrics: a review on cattle identification and tracking[J]. Computers and Electronics in Agriculture, 2016, 123: 423-435.
- [5] Dhakad S K, Dwivedi U, Baudha S, et al. Performance improvement of fractal antenna with electromagnetic band gap (EBG) and defected ground structure for wireless communication[M]// Gnanagurunathan G, Sangeetha R G, Kiran K U. Optical and microwave technologies. Lecture notes in electrical engineering. Singapore: Springer, 2017, 468: 9-19.
- [6] Xiong S H, Sun Z H. Design of milk yield monitoring system based on RFID and image processing[J]. Computer Applications and Software, 2018, 35(7): 267-272.
- 熊双辉, 孙振华. 基于 RFID 和图像处理的奶牛测产系统设计[J]. 计算机应用与软件, 2018, 35(7): 267-272.
- [7] Xu W H, Pei Y J, Gao D L, et al. Mass classification of breast mammogram based on attention mechanism and transfer learning [J]. Laser & Optoelectronics Progress, 2021, 58(4): 0410007.
- 许文慧, 裴以建, 郜冬林, 等. 基于注意力机制与迁移学习的乳腺钼靶肿块分类[J]. 激光与光电子学进展, 2021, 58(4): 0410007.
- [8] Chang J, Guan S Q, Shi H Y, et al. Strip defect classification based on improved generative adversarial networks and MobileNetV3[J]. Laser & Optoelectronics Progress, 2021, 58(4): 0410016.
- 常江, 管声启, 师红宇, 等. 基于改进生成对抗网络和 MobileNetV3 的带钢缺陷分类[J]. 激光与光电子学进展, 2021, 58(4): 0410016.
- [9] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector [EB/OL]. (2015-12-08) [2020-09-15]. <https://arxiv.org/abs/1512.02325>.
- [10] Dev S, Wen B H, Lee Y H, et al. Ground-based image analysis: a tutorial on machine-learning techniques and applications[J]. IEEE Geoscience and Remote Sensing Magazine, 2016, 4(2): 79-93.
- [11] Su H S, Liu T T, Liu G H, et al. Algorithm for student behavior detection based on neural network [J]. Laser & Optoelectronics Progress, 2020, 57(22): 221016.
- 苏寒松, 刘腾腾, 刘高华, 等. 基于神经网络的学生

- 行为检测算法研究[J]. 激光与光电子学进展, 2020, 57(22): 221016.
- [12] Xu J H, Shao M Y, Wang Y C, et al. Recognition of corn leaf spot and rust based on transfer learning with convolutional neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 230-236, 253.
许景辉, 邵明烨, 王一琛, 等. 基于迁移学习的卷积神经网络玉米病害图像识别[J]. 农业机械学报, 2020, 51(2): 230-236, 253.
- [13] Xu X F, Zhao W F, Zou H Q, et al. The wearing and testing method of helmet based on mobilenet SSD [J/OL]. Computer Engineering: 1-17 [2021-06-10]. <https://doi.org/10.19678/j.issn.1000-3428.0058733>.
徐先峰, 赵万福, 邹浩泉, 等. 基于 MobileNet-SSD 的安全帽佩戴检测方法 [J/OL]. 计算机工程: 1-17 [2021-06-10]. <https://doi.org/10.19678/j.issn.1000-3428.0058733>.
- [14] Dong Y C, Shan Y G, Yuan J. Pedestrian detection based on improved SSD [J]. Computer Engineering and Design, 2020, 41(10): 2921-2926.
董永昌, 单玉刚, 袁杰. 基于改进 SSD 算法的行人检测方法 [J]. 计算机工程与设计, 2020, 41(10): 2921-2926.